

文章编号 1004-924X(2018)02-0426-09

## 利用区域增长技术的自适应高光谱图像分类

吴银花\*, 胡炳樑, 高晓惠, 周安安

(中国科学院 西安光学精密机械研究所, 陕西 西安 710119)

**摘要:** 针对面向对象的高光谱分类方法中分割参数设置问题, 提出了一种基于区域增长技术的自适应高光谱分类算法。首先提出了带约束的区域增长方法, 利用已知训练样本的空间信息, 提供有效约束, 从而降低区域增长过程中区域标记的错误传播率, 以提高分类性能; 其次, 提出了自适应阈值计算方法, 通过分析已知训练样本光谱的分布规律, 自适应地计算出合理的区域划分阈值, 从而代替经验阈值, 提高算法的鲁棒性; 最后, 采用 K 近邻算法(KNN), 对划分后各区域中心进行分类。实验结果表明: 对于不同图像, 提出的算法计算出的自适应阈值均与其经验值相符合, 且其分类效果优于其他算法, 来自 AVIRIS 传感器的高光谱数据 Indian Pines 在 10% 的已知训练样本下总体分类精度达 92.94%、kappa 系数达 0.919 5, 来自 ROSIS 传感器的高光谱数据 Pavia University 在 5% 的已知训练样本下总体分类精度达 95.78%、kappa 系数达 0.944 0。该算法不仅增强了算法的鲁棒性, 同时有效提高了分类性能, 在高光谱应用中具有较强的实用性。

**关键词:** 高光谱; 分类; 面向对象; 区域增长; 自适应

**中图分类号:** TP751.1 **文献标识码:** A **doi:** 10.3788/OPE.20182602.0426

## Adaptive hyperspectral image classification using region-growing techniques

WU Yin-hua\*, HU Bing-liang, GAO Xiao-hui, ZHOU An-an

(Xi'an institute of optics and precision mechanics, Chinese Academy of Sciences, Xi'an 710119, China)

\* Corresponding author, E-mail: yinhuawoo@163.com

**Abstract:** Aiming at the problem of segmentation parameters setting in object-oriented hyperspectral classification method, an adaptive hyperspectral classification algorithm based on region-growing techniques was proposed in this paper. Firstly, a constrained region-growing method was proposed, which used the spatial information of the training samples to provide effective constraints, thus reducing the error propagation rate of the region markers in the region-growing process, and improving classification performance. Secondly, an adaptive threshold calculation method was proposed. By analyzing the distribution law of the spectrum of the training samples, the reasonable threshold for region division was calculated adaptively to replace the empirical threshold, so that the robustness of the algorithm was improved. Finally, the K-nearest neighbor algorithm (KNN) was used to classify the centers of each region after division. Experimental results show that: For different images, the adaptive thresholds calculated by the method are consistent with the empirical values, and the classification effect of

收稿日期: 2017-05-27; 修订日期: 2017-07-21.

基金项目: 国家自然科学基金资助项目(No. 11327303); 国家国际科技合作专项资助项目(No. 2015DFA10140); 国家自然科学基金资助项目(No. 61405239)

the proposed algorithm is better than other algorithms. For hyperspectral data Indian Pines from AVIRIS sensor, the overall classification accuracy and kappa are 92.94% and 0.9195 respectively with 10% training samples, and for hyperspectral data Pavia University from ROSIS sensor, the overall classification accuracy and kappa are 95.78% and 0.9440 respectively with 5% training samples. The proposed algorithm not only enhances the robustness of the algorithm, but also improves the classification performance effectively, and has strong practicability in hyperspectral applications.

**Key words:** hyperspectral; classification; object-oriented; region-growing; adaptive

## 1 引言

高光谱成像技术将空间维与光谱维信息融为一体,大幅提高了精细信息的表达能力,在空间遥感、农业、食品检测及生命科学等多个领域<sup>[1-4]</sup>得到了十分广泛地应用。高光谱分类技术,作为高光谱遥感影像处理和应用的核心内容之一,自高光谱成像技术被提出以来得到了迅猛地发展<sup>[5]</sup>,形成了一系列经典算法,如最大似然判别法<sup>[6]</sup>、支持向量机<sup>[7]</sup>、神经网络<sup>[8]</sup>、K近邻算法<sup>[9]</sup>以及稀疏理论<sup>[10]</sup>等。然而,由于大气传输过程中的混合效应、仪器本身和周围环境的影响,常导致“同物异谱、同谱异物”现象的发生。而上述的经典分类算法多是以像元作为基本单元,主要利用地物的诊断性光谱特征进行分类,并未考虑遥感图像的空间域特征,从而无法有效处理这类现象,分类结果往往达不到预期效果。

由于真实地表物体的分布呈现区域性,相邻像元间总存在一定的相关性,尤其是空间分辨率较高的高光谱图像<sup>[11]</sup>。基于面向对象的高光谱分类方法,合理利用地理空间对象的分布规律,有效地改善了基于光谱特征的分类结果中麻点问题,成为遥感影像分类一个新的研究热点。其中,最关键的问题是图像分割,即将分类的基本单元从像元转换到对象。利用区域增长<sup>[12]</sup>、分水岭分割<sup>[13]</sup>等方法进行高光谱图像分割,均取得了较好的效果。但这些方法中,分割参数往往是针对特定图像设置的经验值,因此无法较好地适应不同图像。后来出现的基于超像元的分类方法<sup>[14-15]</sup>,其基本单元是尺度介于像元与对象间的超像元。该方法利用过分割方式,在一定程度上缓解了尺度参数设置问题,但仍需要采用经验值,为不同图像设置超像元数量等参数。可见,上述面向对象的分类算法中,由于分割相关参数采用了经验值,

算法的鲁棒性较差。而参数设置的不合理,将可能导致欠分割或过分割现象,造成目标对象的混合分布,从而会影响分类精度。

针对分割参数的设置问题,本文结合邻近算法(K-Nearest Neighbor, KNN),提出了基于区域增长技术的自适应高光谱分类算法。一方面,提出了带约束的区域增长方法,尽可能避免错误区域标记的传播,从而提高分类性能;另一方面提出了自适应阈值计算方法,通过分析先验信息,自动计算出合理的分割阈值,从而有效解决参数设置所带来的影响,显著提高算法的鲁棒性。

## 2 原理与算法

### 2.1 带约束的区域增长方法

文献[12]提出了一种利用欧氏距离先进行空间邻域自动聚类,然后对各个聚类中心再分类的方法,工作机制简单,却有效地克服了分类结果中麻点现象,是较经典的基于面向对象的分类方法。具体方法如下:分块矩阵  $S$  中每个元素表示在高光谱图像对应空间坐标处像元所属的区域标记,阈值  $TH$  用于控制区域增长过程。如图1所示, Z型(从左到右、从上到下)扫描高光谱图像中每个像元,采用欧式距离度量当前像元与其相邻的已进行区域标记的像元间的光谱相似性,距离越小,相似度越高,将相似度最高的相邻像元与当前像元间距离  $D$  与阈值  $TH$  进行比较,若  $D < TH$ ,二者相似度较高,将当前像元标记为与该相邻像元相同的区域,否则,二者相似度较低,将当前像元标记为新的区域。完成区域标记后,再通过适当的分类方法,对各区域中心进行分类。

高光谱图像中常存在同谱异物现象,即不同物质的光谱差异性很小。主要表现为以下两种情况:一是两种物质的光谱曲线确实非常相似或者差异很小;二是由于混合效应,空间相邻的两种物




图 1 区域增长扫描示意图

Fig. 1 Scanning diagram of region growing

质边界区域像元光谱呈现渐变的趋势,从而边界区域的像元间光谱差异较小。可见,对于上述两种情况,文献[12]的方法容易将空间相邻的不同物质归为同一个区域,从而最终划分为同一个类别,导致误分现象,降低了分类准确度。

而基于面向对象的分类方法,其基本单元是对象,即最终将一个对象内所有像元标记为同一个类别。因此,同一个区域内不能容纳不同类别的样本。本文正是利用这一点,提出了带约束的区域增长方法,努力避免区域标记的错误传播,以提高分类性能。具体方法如下:

为了减小计算量,先采用线性判别分析(Linear Discriminant Analysis, LDA)进行数据降维,然后通过 Z 型扫描逐像元进行区域标记。每个像元的区域标记过程主要包括以下两个步骤:

步骤 1: 预测。对当前像元  $X$ , 首先利用文献[12]的方法, 根据与其相邻的已进行区域标记的像元信息, 预测该像元可能划入的区域, 记为  $P$ ;

步骤 2: 约束判断。根据约束条件, 判断是否将当前像元  $X$  最终标记为步骤 1 中获取的预测区域  $P$ 。其中, 约束条件是同一个区域内不能存在不同类别的已知训练样本。具体判断过程如图 2 所示。

## 2.2 自适应阈值计算方法

对于区域增长技术, 阈值设置是关键问题之一, 设置过大, 容易将不同物质归为一个区域, 设置过小, 起不到面向对象分类的作用。而且, 阈值的设置还会受到如地物分布复杂度、不同物质间光谱差异性、是否进行降维等因素的影响。为了使算法具有良好的鲁棒性, 本文提出了自适应阈值计算方法, 根据高光谱图像的不同特性, 能够自

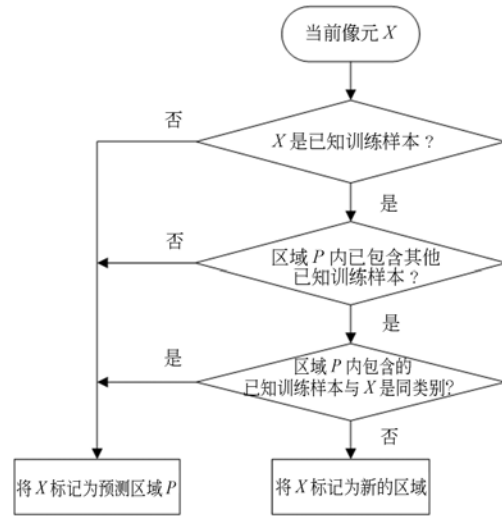


图 2 约束判断过程

Fig. 2 Judgment process with constraint


动计算出合理的分割阈值, 而不再采用经验值设置方式。

阈值与像元间欧式距离相关。显然, 同类别像元间距离较小, 不同类别像元间距离较大, 阈值应处于这二者之间, 并尽可能划分这两种距离。为了研究同类别像元间距离的分布规律, 本文分别从两组数据 Indian Pines 和 Pavia University (详见实验部分), 每类地物随机选取 15% 作为已知训练样本进行分析。在已知训练样本范围内, 计算每类地物的中心及每个样本到其对应类别中心的距离, 形成距离数组, 并进行直方图分析, 如图 3 所示。


从图 3 可以看出, 像元到对应类别中心的距离分布曲线呈现单峰特性, 且不考虑距离特别大的情况下大致对称, 可认为近似服从正态分布。本文中, 为了尽可能避免欠分割或过分割现象, 折中考虑阈值, 而对于正态分布, 变量取均值时其概率最大, 且均值两侧分别占 50% 的概率。因此, 建立如下计算模型: 将已知训练样本中各像元到对应类别中心的距离, 求取平均值, 设置为阈值, 如公式(1)所示:

$$TH = \frac{\sum_i \sum_j |X_{ij} - a_i|}{N}, \quad (1)$$

其中:  $TH$  是求得的阈值,  $X_{ij}$  是已知训练样本,  $i$  是类别,  $j$  是同类别中样本序号,  $a_i$  是每个类别的中心,  $N$  是所有已知训练样本数量。



(a) Indian Pines 直方图  
(a) Indian Pines histogram



(b) Pavia University 直方图  
(b) Pavia University histogram

图 3 同类别像元间距离分布

Fig. 3 Distribution of distance between same category pixels

### 2.3 算法描述

根据 2.1~2.2 的描述,本文算法具体步骤如下:

步骤 1:根据 2.2 中的方法,统计分析已知训练样本,自适应地计算控制区域增长过程的阈值  $TH$ ;

步骤 2:根据 2.1 中的方法,基于自适应阈值  $TH$ ,从左到右、从上到下逐像元扫描,实现区域增长;

步骤 3:完成区域标记后,利用 KNN 算法(邻近数为 1),对各个区域的中心进行分类。


## 3 实验结果及分析

### 3.1 实验数据

为了验证该算法的可行性和有效性,本文选

用具有代表性的高光谱数据 Indian Pines 和 Pavia University 进行相关实验。这两组数据是公开的高光谱基准图像,且来自不同的传感器,通过这两组数据验证的算法具有较广泛的适用性。

(1)Indian Pines:由 AVIRIS 传感器在美国印第安纳州的一处农业用实验区获取的高光谱图像,大小为  $145 \text{ pixel} \times 145 \text{ pixel}$ ,空间分辨率为  $20 \text{ m}$ ,包含 16 种典型地物,具有 224 个波段,去除水吸收波段和噪声较大的波段后,剩余的 200 个波段数据参与实验。




(a) 伪彩色图 (a) False-color map  
(b) 真实地物标记图 (b) Ground-truth map

图 4 Indian Pines 高光谱数据

Fig. 4 Indian Pines hyperspectral image

(2)Pavia University:由 ROSIS 传感器在意大利北部获取的高光谱图像,大小为  $610 \text{ pixel} \times 340 \text{ pixel}$ ,空间分辨率为  $1.3 \text{ m}$ ,包含 9 种典型地物,具有 115 个波段,去除水吸收波段后,剩余的 103 个波段数据参与实验。



(a) 伪彩色图 (a) False-color map  
(b) 真实地物标记图 (b) Ground-truth map

图 5 Pavia University 高光谱数据

Fig. 5 Pavia University hyperspectral image

### 3.2 实验设置

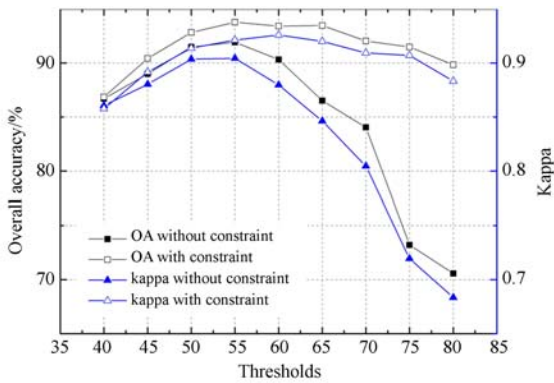
由于高光谱数据往往含有大量噪声,进行分

类处理之前,有必要对高光谱数据先进行空间滤波等预处理。本文将采用  $5 \times 5$  高斯滤波器,对上述两组数据进行预处理。

本文共进行了 3 组仿真实验,使用总体精度(OA)和 kappa 系数作为分类性能评价指标,为提高实验的可靠性和精确度,对每组实验方案,重复运行 10 次仿真,每次仿真随机选取一定比例的样本作为已知训练样本,其余为测试样本,并将 10 次仿真结果取平均作为最终结果。

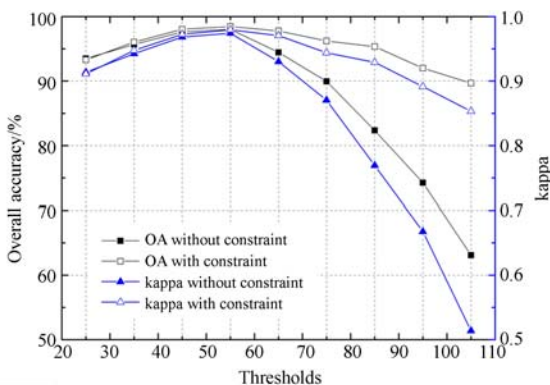
### 3.3 第 1 组仿真实验

为了验证 2.1 节中提出的带约束的区域增长方法,从 Indian Pines、Pavia University 中每类地物分别随机选取 10% 作为已知训练样本,分别用 2.1 节的方法和文献[12]的方法,即约束和不约束的情况下,针对不同阈值进行分类,实验结果如图 6 所示。



(a) Indian Pines 数据

(a) Data of Indian Pines



(b) Pavia University 数据

(b) Data of Pavia University

图 6 区域增长约束比较

Fig. 6 Comparison of region growing constraint

从图 6 可以看出,阈值较小时,约束和不约束的情况下,分类性能相似,差异很小;而阈值较大时,约束的情况下,两组数据的总体精度和 kappa 系数,均大于不约束的情况,且随着阈值的增大,二者差异逐渐增大。这是因为随着阈值的增大,一个区域能覆盖的像元越多,不同类别的像元归为同一类的概率就越大,这时区域增长约束的效果越显著。

### 3.4 第 2 组仿真实验

从图 6 可以看出,当采用 2.1 节中区域增长方法时,对于高光谱数据 Indian Pines,阈值取 45~75 时算法性能较好,总体精度均高于 90%;对于高光谱数据 Pavia University,阈值取 35~85 时算法性能较好,总体精度均高于 95%。因此可将上述范围设定为已知训练样本比例为 10% 时对应图像的阈值经验值。

为了验证 2.2 节中提出的自适应阈值计算方法,在不同已知训练样本比例下,用上述方式寻找该两组数据的阈值经验值;同时,利用 2.2 节的方法计算出对应已知训练样本比例下的自适应阈值,进行比较,结果如表 1 所示。

表 1 自适应阈值

Tab. 1 Adaptive threshold

高光谱数据	已知训练样本比例/%	经验值	自适应阈值
Indian Pines	10	45~75	53.81
	15	45~85	59.96
	20	45~95	62.94
Pavia University	5	35~65	58.40
	10	35~85	72.23
	15	35~90	77.96


从表 1 可以看出,随着已知训练样本比例的增加,阈值经验值范围变宽,这是因为已知训练样本数量增多时,约束能力增强,在较大阈值下仍能保持较好的分类性能。2.2 节中方法计算得出的 Indian Pines 和 Pavia University 的自适应阈值均正好落入对应阈值经验值范围,说明本文提出的自适应阈值计算方法合理有效。

### 3.5 第 3 组仿真实验

为了验证本文算法的整体分类性能,从 Indi-

an Pines、Pavia University 中每类地物分别随机选取 10%、5%作为已知训练样本,将本文算法与基于光谱特征的经典分类算法和整合空间-光谱特征的分类算法进行了比较。其中,基于光谱特征的分类算法包括 MNF+SVM(9 阶多项式,一对多策略)、LDA+Bayes(朴素 Bayes)、LDA+

KNN(邻近数为 1);整合空间-光谱特征的分类算法是 LDA+WSSD\_KNN<sup>[16]</sup>(邻近数为 1,窗口大小为 13),该算法将加权空谱距离与 KNN 算法相结合进行类别判定。分类结果如图 7、图 8 所示,实验数据如表 2、表 3 所示。



(a) MNF+SVM (b) LDA+Bayes (c) LDA+KNN (d) LDA+WSSD\_KNN (e) 本文算法  
 (a) MNF+SVM (b) LDA+Bayes (c) LDA+KNN (d) LDA+WSSD\_KNN (e) Our method


图 7 Indian Pines 不同算法分类结果图

Fig. 7 Classification results of Indian Pines under different algorithms

表 2 Indian Pines 在不同算法下的分类性能

Tab. 2 Classification performances of Indian Pines under different algorithms

序号	类别	训练样本	测试样本	MNF+SVM	LDA+Bayes	LDA+KNN	LDA+WSSD_KNN	本文算法
1	Alfalfa	5	41	69.76%	4.63%	64.15%	68.29%	67.56%
2	Corn-notill	143	1 285	91.31%	79.67%	78.82%	83.04%	90.09%
3	Corn-mintill	83	747	79.84%	70.43%	74.46%	75.90%	90.50%
4	Corn	24	213	77.32%	41.60%	72.30%	79.81%	84.74%
5	Grass-pasture	49	343	90.67%	91.27%	91.89%	87.10%	94.38%
6	Grass-trees	73	657	97.35%	98.05%	97.90%	97.72%	98.36%
7	Grass-pasture-mowed	3	25	87.60%	0.00%	76.40%	92.00%	94.40%
8	Hay-windrowed	48	430	98.07%	99.60%	99.95%	100.00%	99.86%
9	Oats	2	18	61.11%	0.00%	53.89%	61.11%	60.56%
10	Soybean-notill	98	874	85.72%	66.73%	76.00%	75.17%	90.34%
11	Soybean-mintill	246	2 209	89.19%	85.71%	81.34%	82.34%	93.40%
12	Soybean-clean	60	533	90.36%	74.33%	82.16%	86.68%	91.57%
13	Wheat	21	184	99.40%	95.65%	99.24%	99.46%	99.29%
14	Woods	127	1 138	98.41%	95.44%	95.93%	96.66%	96.9%
15	Buildings-Grass-Trees-Drives	39	347	79.08%	78.01%	83.43%	80.40%	87.03%
16	Stone-Steel-Towers	10	83	89.64%	54.58%	90.96%	93.98%	92.29%
—	总体精度(OA)	—	—	90.08%	82.01%	84.49%	85.64%	92.94%
—	Kappa 系数	—	—	0.886 7	0.792 8	0.822 9	0.836 0	0.919 5



(a) MNF+SVM (b) LDA+Bayes (c) LDA+KNN (d) LDA+WSSD\_KNN (e) 本文算法  
 (a) MNF+SVM (b) LDA+Bayes (c) LDA+KNN (d) LDA+WSSD\_KNN (e) Our method

图 8 Pavia University 不同算法分类结果图

Fig. 8 Classification results of Pavia University under different algorithms

表 3 Pavia University 在不同算法下的分类性能

Tab. 3 Classification performances of Pavia University under different algorithms (%)

序号	类别	训练样本	测试样本	MNF+SVM	LDA+Bayes	LDA+KNN	LDA+WSSD_KNN	本文算法
1	Asphalt	133	6 498	93.53	92.83	91.76	91.70	93.63
2	Meadows	373	18 276	97.96	90.58	96.39	96.24	98.05
3	Gravel	42	2 057	77.18	71.12	74.89	76.68	96.41
4	Trees	62	3 002	92.14	94.73	92.59	94.40	94.59
5	Painted metal sheets	27	1 318	99.13	99.98	99.96	99.92	99.52
6	Bare Soil	101	4 928	90.52	82.38	83.24	87.17	97.27
7	Bitumen	27	1 303	60.64	79.04	84.46	83.06	97.34
8	Self-Blocking Bricks	74	3 608	86.68	81.86	80.31	81.33	89.79
9	Shadows	19	928	99.80	97.21	99.58	99.56	76.23
—	总体精度(OA)	—	—	92.91	88.64	91.23	91.87	95.78
—	Kappa 系数	—	—	0.905 7	0.850 5	0.883 3	0.892 3	0.944 0

实验结果表明,分类性能从高到底依次是本文算法、MNF+SVM、LDA+WSSD\_KNN、LDA+KNN、LDA+Bayes。其中,同样结合KNN的本文算法和LDA+WSSD\_KNN算法,均比基于光谱特征的LDA+KNN算法具有更高的分类性能,这是因为这两种算法整合了空间-光谱特征,合理利用高光谱数据中的空间信息,改善了整体分类性能。相比其他算法,显然本文算法的总体精度、kappa系数和绝大多数类别的分类精度均有了明显提高。根据表2、表3的实验数据,相比于基于光谱特征的分类型算法,本文算法的总体分类精度提升了2.86~10.93%,kappa系数提升了0.032 8~0.126 7;相比于整合空间-光谱特征

的LDA+WSSD\_KNN算法,本文算法的总体分类精度提升了3.91~7.30%,kappa系数提升了0.051 7~0.083 5。

图9是从Indian Pines、Pavia University中每类地物选取不同比例样本作为已知训练样本的情况下,不同算法的总体分类精度比较结果。可以看出,在不同已知训练样本比例下,本文算法的总体分类精度均高于其他算法,从而进一步验证了本文算法的分类性能。同时,还可以看出,随着已知训练样本比例的不断增多,各算法总体精度也随之提高。这是因为随着已知训练样本数量的增加,所能获取的先验信息增多,各算法的鉴别能力增强,从而分类精度也提高。

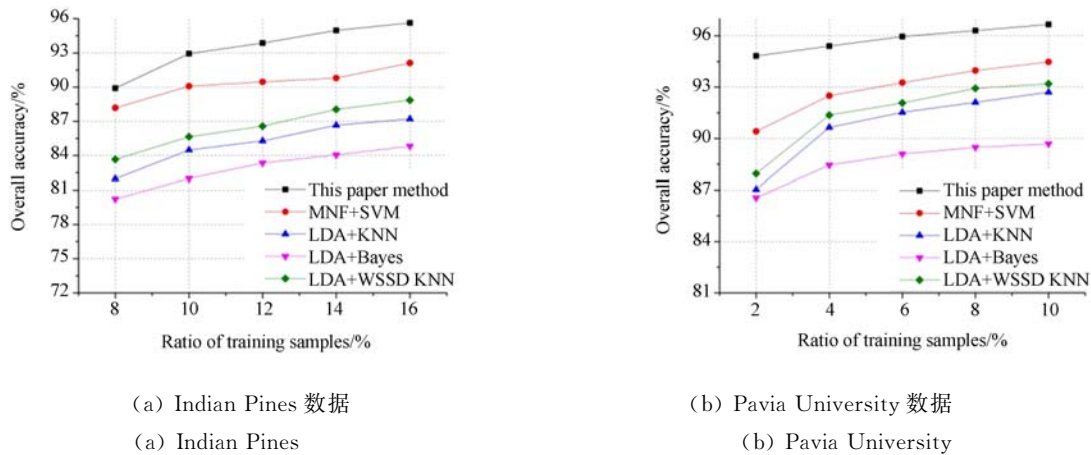


图9 不同已知训练样本比例下不同算法的总体精度比较

Fig. 9 Comparison of OA for different algorithms with different ratios of training samples

## 4 结 论

本文为了提高分类算法的鲁棒性,提出了自适应阈值计算方法,为了提高算法的分类性能,提出了带约束的区域增长方法,并结合 KNN 算法,最终提出了基于区域增长技术的自适应高光谱分类算法。实验结果表明,通过本算法计算得出的区域增长阈值与其经验值十分吻合,且对于不同图像均得到了较好的分类效果,来自不同传感器

的高光谱数据 Indian Pines 和 Pavia University, 分别在 10% 和 5% 的已知训练样本比例下,总体分类精度达到了 92.94% 和 95.78%。

而随着已知训练样本比例的增加,本文算法的分类性能逐渐提高,即已知训练样本的数量越多越好。然而这些已标记样本的获取往往比较困难、代价较高,所以常面临小样本问题。因此,本文下一步工作是基于半监督思想,研究利用有限的已标记样本,挖掘大量未标记样本的方法。

### 参考文献:

- [1] 张成业, 秦其明, 陈理, 等. 高光谱遥感岩矿识别的研究进展[J]. 光学精密工程, 2015, 23(8): 2407-2418.
- ZHANG CH Y, QIN Q M, CHEN L, *et al.*. Research and development of mineral identification utilizing hyperspectral remote sensing[J]. *Opt. Precision Eng.*, 2015, 23(8): 2407-2418. (in Chinese)
- [2] JIAO Q J, ZHANG B, LIU J G, *et al.*. A novel two-step method for winter wheat-leaf chlorophyll content estimation using a hyperspectral vegetation index[J]. *International Journal of Remote Sensing*, 2014, 35(21): 7363-7375.
- [3] 鲍一丹, 陈纳, 何勇, 等. 近红外高光谱成像技术快速鉴别国产咖啡豆品种[J]. 光学精密工程, 2015, 23(2): 349-355.
- BAO Y D, CHEN N, HE Y, *et al.*. Rapid identification of coffee bean variety by near infrared hyperspectral imaging technology [J]. *Opt. Precision Eng.*, 2015, 23(2): 349-355. (in Chinese)
- [4] 龚小进, 王刚, 欧中华, 等. 高光谱成像技术在生物学中的应用[J]. 激光生物学报, 2016, 25(4): 289-314.
- GONG X J, WANG G, OU ZH H, *et al.*. The application of hyperspectral imaging technique in biomedicine[J]. *Acta Laser Biology Sinica*, 2016, 25(4): 289-314. (in Chinese)
- [5] 张兵. 高光谱图像处理与信息提取前沿[J]. 遥感学报, 2016, 20(5): 1062-1090.
- ZHANG B. Advancement of hyperspectral image processing and information extraction[J]. *Journal of Remote Sensing*, 2016, 20(5): 1062-1090. (in Chinese)
- [6] RICHARDS J A, JIA X P. *Remote Sensing Digital Image Analysis: an Introduction*[M]. 4th ed. Berlin: Springer Verlag, 2006.
- [7] DU P J, TAN K, XING X S. A novel binary tree support vector machine for hyperspectral remote

- sensing image classification[J]. *Optics Communications*, 2012, 285(13-14): 3054-3060.
- [8] 郭文川, 董金磊. 高光谱成像结合人工神经网络无损检测桃的硬度[J]. *光学精密工程*, 2015, 23(6): 1530-1537.
- GUO W CH, DONG J L. Nondestructive detection on firmness of peaches based on hyperspectral imaging and artificial neural networks[J]. *Opt. Precision Eng.*, 2015, 23(6): 1530-1537. (in Chinese)
- [9] 周志华. *机器学习*[M]. 北京: 清华大学出版社, 2016.
- ZHOU Z H. *Machine Learning*[M]. Beijing: Tsinghua University Press, 2016. (in Chinese)
- [10] QIAN Y T, YE M C, ZHOU J. Hyperspectral image classification based on structured sparse logistic regression and three-dimensional wavelet texture features[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2013, 51(4): 2276-2291.
- [11] 唐中奇, 付光远, 陈进, 等. 基于多尺度分割的高光谱图像稀疏表示与分类[J]. *光学精密工程*, 2015, 23(9): 2708-2714.
- TANG ZH Q, FU G Y, CHEN J, *et al.*. Multi-scale segmentation-based sparse coding for hyperspectral image classification[J]. *Opt. Precision Eng.*, 2015, 23(9): 2708-2714. (in Chinese)
- [12] 耿修瑞, 张霞, 陈正超, 等. 一种基于空间连续性的高光谱图像分类方法[J]. *红外与毫米波学报*, 2004, 23(4): 299-302.
- GENG X R, ZHANG X, CHEN ZH CH, *et al.*. Classification algorithm based on spatial continuity for hyperspectral image[J]. *Journal of Infrared and Millimeter Waves*, 2004, 23(4): 299-302. (in Chinese)
- [13] TARABALKA Y, CHANUSSOT J, BENEDIKTSSON J A. Segmentation and classification of hyperspectral images using watershed transformation[J]. *Pattern Recognition*, 2010, 43(7): 2367-2379.
- [14] LI S S, JIA X P, ZHANG B. Superpixel-based Markov random field for classification of hyperspectral images[C]. *Proceedings of the 2013 IEEE International Geoscience and Remote Sensing Symposium*, IEEE, 2013, 3491-3493.
- [15] FANG L Y, LI S T, KANG X D, *et al.* Spectral-spatial classification of hyperspectral images with a superpixel-based discriminative sparse model[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, 53(8): 4186-4201.
- [16] 黄鸿, 郑新磊. 加权空-谱与最近邻分类器相结合的高光谱图像分类[J]. *光学精密工程*, 2016, 24(4): 873-881.
- HUANG H, ZHENG X L. Hyperspectral image classification with combination of weighted spatial-spectral and KNN[J]. *Opt. Precision Eng.*, 2016, 24(4): 873-881. (in Chinese)

#### 作者简介:



吴银花(1984—),女,吉林延吉人,博士后,2007年于吉林大学获得学士学位,2012年于中国科学院大学获得博士学位,主要从事高光谱数据处理和高光谱成像技术方面的研究。E-mail: yinhuawoo@163.com

#### 导师简介:



胡炳樑(1973—),男,湖南湘乡人,博士,研究员,博士生导师,1995年于华中科技大学获得学士学位,2003年、2007年于中国科学院大学分别获得硕士、博士学位,主要从事光谱成像技术、高速信号处理、光谱数据处理方面的研究。E-mail: hbl@opt.ac.cn